


## Breve revisión del tema

### Introducción

Obtener datos espacio-temporales continuos y automatizados sobre uso de infraestructura vial y espacio público (vehículos, buses, peatones, ciclistas, etc.) desde cámaras de video; usando datos abiertos, para caracterizar el uso del espacio público. Brindar herramientas para empoderar a los ciudadanos sobre temas de movilidad y uso del espacio público.



### Justificación

- ▶ Levantar información para la toma de decisiones.
- ▶ Los conteos manuales son costosos (personal y tiempo).
- ▶ Datos no publicados de manera estandarizada para reportes.

### Planteamiento de hipótesis

- ▶ Obtener un error aceptable en detección, clasificación, y rastreo de los objetos en el video.
- ▶ En dispositivo embarcado (cámara de video) y servidor, para generar reportes automatizados.

### Materiales

- Visión por computadora:** técnicas de aprendizaje supervisado (Machine Learning), Redes Neuronales Convolucionales, p.e. Single Shot Detector (SSD).
- Infraestructura de Datos Espaciales (IDE)** en plataforma remota para publicar de manera estandarizada (OGC-SOS) los datos de series de tiempo sobre el número de usuarios según la hora del día.
- Procesamiento en la WEB** (OGC-WPS) para la generación automatizada de reportes.




Figura 1: Mapa de ruido basado en conteos, centro de Cuenca.

## Resultados

### SVM vs SSD-Mobilenet vs MBF (Raspberry Pi)

Cuadro 1: Métricas de desempeño SSD, SVM y MBF

	Model	Cars			Bicycles			Buses			People		
		R1	R2	R3	R1	R2	R3	R1	R2	R3	R1	R2	R3
REC	SVM	0,54	0,86	0,69	0,08	0	0,10	0	0	0	0	0	0,03
	SSD	0,81	0,93	0,84	0,16	0	0	0,40	0,92	0,94	0,31	0,05	0,01
	MBF	0,62	0,37	0,66	0,88	0,90	0,63	0,72	0,76	0,83	0,41	0,81	0,62
PRE	SVM	0,91	0,94	0,89	0,13	0	0,50	0	0	0	0	0	0,25
	SSD	0,72	0,67	0,64	0,50	0	0	0,29	0,38	0,21	0,75	0,50	0,50
	MBF	0,76	0,97	0,56	0,69	0,18	0,50	0,39	0,16	0,47	0,71	0,77	0,97
F1	SVM	0,67	0,89	0,75	0	0	0,17	0	0	0	0	0	0,05
	SSD	0,71	0,65	0,65	0,24	0	0	0,25	0,34	0,34	0,43	0,02	0,02
	MBF	0,76	0,53	0,79	0,67	0,31	0,66	0,54	0,28	0,56	0,81	0,73	0,76

Note: R1= 640x480 , R2= 1280x720 and R3=1920x1080

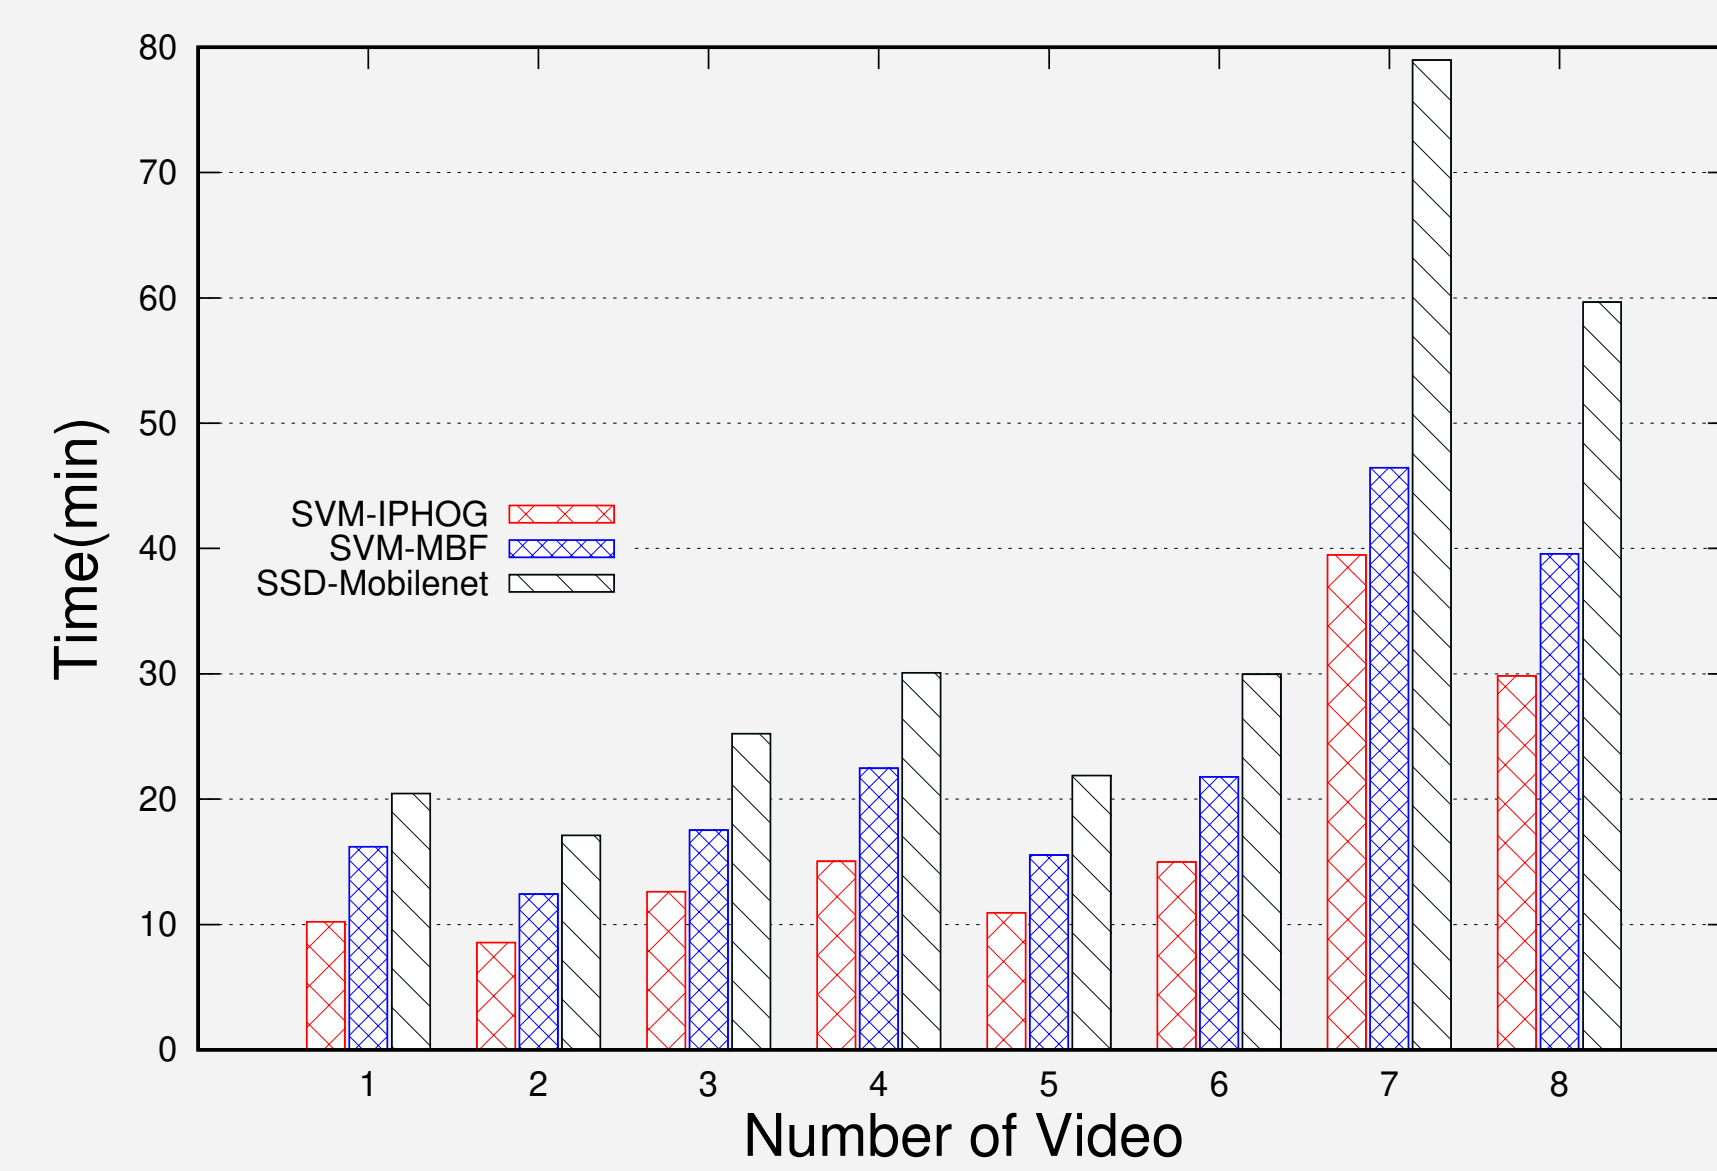


Figura 2: Tiempos de ejecución SVM, SSD y MBF.

### SSD-Mobilenet (Raspberry Pi + Movidius)

Cuadro 2: Combinaciones de Hardware y Modelo SSD-Mobilenet

Hardware	Type of training (SSD-Mobilenet)	
	Own trained model	Pre-trained model
Rpi + NCS	Test A	Test B
Rpi	Test C	Test D

Cuadro 3: Métricas de desempeño para el sistema de conteo y clasificación.

	Test A			Test B			Test C			Test D		
	REC	PRE	F1	REC	PRE	F1	REC	PRE	F1	REC	PRE	F1
Car	0,91	0,97	0,94	0,92	0,87	0,89	0,89	0,95	0,92	0,86	0,68	0,71
Person	0,99	0,68	0,79	0,56	0,89	0,59	0,97	0,66	0,77	0,12	0,58	0,18
Motorcycle	0,81	0,93	0,83	0,34	0,75	0,43	0,79	0,91	0,81	0,05	0,17	0,08
Bus	0,91	0,87	0,86	0,88	0,64	0,68	0,89	0,85	0,84	0,75	0,29	0,34
Truck	0,55	0,64	0,56	-	-	-	0,53	0,62	0,54	-	-	-

Cuadro 4: Número de FPS, bit rate y tiempos de procesado (min).

Resolution	Video	Test A		Test B		Test C		Test D		bit rate (Kbps)
		FPS	Time	FPS	Time	FPS	Time	FPS	Time	
1280x720	1	11,74	6,38	9,99	7,50	0,77	194,81	0,68	220,59	1041
	2	10,41	6,51	10,15	6,68	0,65	230,77	0,54	277,78	921
	3	10,6	7,08	10,26	7,32	0,79	189,87	0,55	272,73	890
640x480	4	18,62	5,63	16,71	6,27	1,12	133,93	0,95	157,89	3700
	5	16,79	7,31	17,41	7,06	1,07	140,19	0,86	174,42	3967
	6	18,68	6,01	17,13	6,61	1,02	147,06	0,81	185,19	3476
1920x1080	7	17,06	7,08	17,01	7,11	0,96	156,25	0,79	189,87	4061
	8	17,05	7,63	17,74	7,34	0,9	166,67	0,86	174,42	3242
	9	17,03	7,80	16,93	7,85	0,85	176,47	0,77	194,81	3013
1920x1080	10	17,86	7,34	16,48	7,95	0,82	182,93	0,78	192,31	2820
	11	8,64	17,43	8,89	19,01	1,32	113,64	0,93	161,29	2074
	12	8,35	17,99	7,73	19,40	1,1	136,36	0,92	163,04	2002
	13	8,69	17,28	7,11	21,10	1,38	108,70	0,98	153,06	1888

### SSD vs GoogleNet (Procesamiento en Servidor)

Cuadro 5: Métricas de desempeño promedio (procesamiento en servidor).

Models	Metrics	Cars	Pedestrians
SSD-Mobilenet re-trained	REC	0,816	0,904
	PRE	0,953	0,681
	F1	0,839	0,706
SSD-Mobilenet pre-trained	REC	0,920	0,598
	PRE	0,852	0,358
	F1	0,883	0,396
GoogLeNet pre-trained	REC	0,811	0,429
	PRE	0,834	0,905
	F1	0,812	0,505

### SSD-Mobilenet (Jetson Nano - Nvidia-GPU)

Cuadro 6: Combinaciones de Hardware y Modelo SSD-Mobilenet.

Hardware	Type of training (SSD-Mobilenet)	
	Own trained model	Pre-trained model
Server	Test A	Test B
Nvidia Jetson Nano	Test C	Test D

Cuadro 7: Métricas de desempeño para el sistema de conteo y clasificación.

	Test A			Test B			Test C			Test D		
	REC	PRE	F1	REC	PRE	F1	REC	PRE	F1	REC	PRE	F1
Car	0,94	0,97	0,95	0,74	0,97	0,83	0,85	0,98	0,90	0,72	0,99	0,82
People	0,84	0,84	0,79	0,92	0,56	0,62	0,85	0,86	0,81	0,87	0,72	0,70
Motorcycle	0,89	0,97	0,92	0,85	0,84	0,80	0,84	0,87	0,81	0,63	0,97	0,73
Bus	0,92	0,94	0,91	0,91	0,56	0,57	0,85	0,93	0,83	0,80	0,47	0,38
Truck	0,85	0,91	0,83	0,93	0,24	0,27	0,72	0,94	0,77	0,93	0,44	0,48
Average	0,89	0,93	0,88	0,87	0,63	0,62	0,82	0,92	0,83	0,79	0,72	0,62

### SSD-Mobilenet (Jetson Nano - Nvidia-GPU)

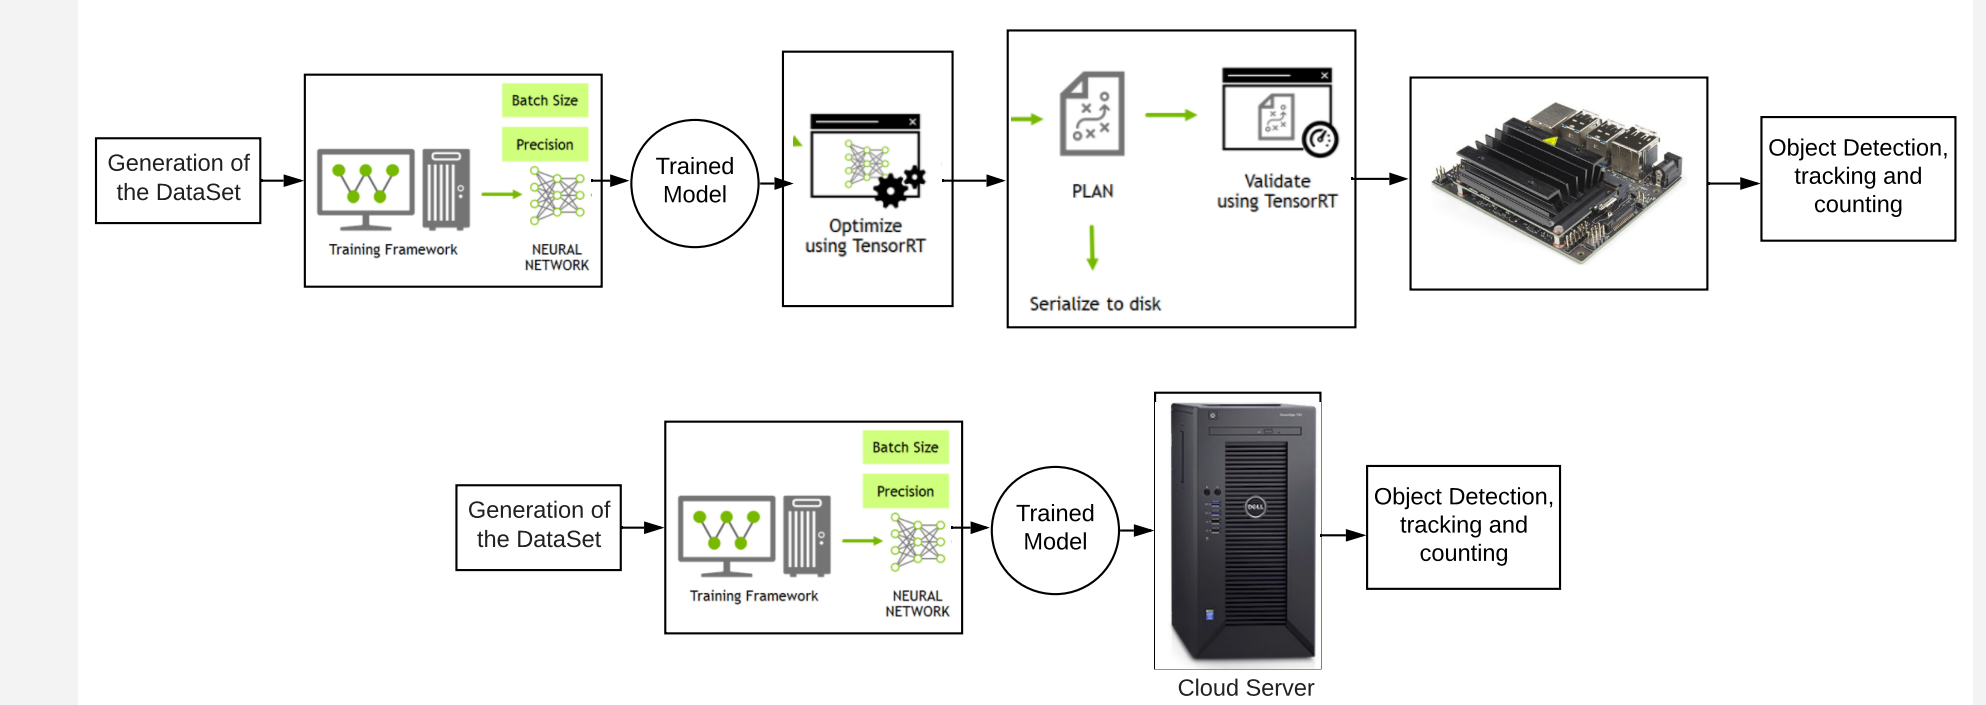


Figura 3: Flujo de trabajo en el servidor y dispositivo embebido.

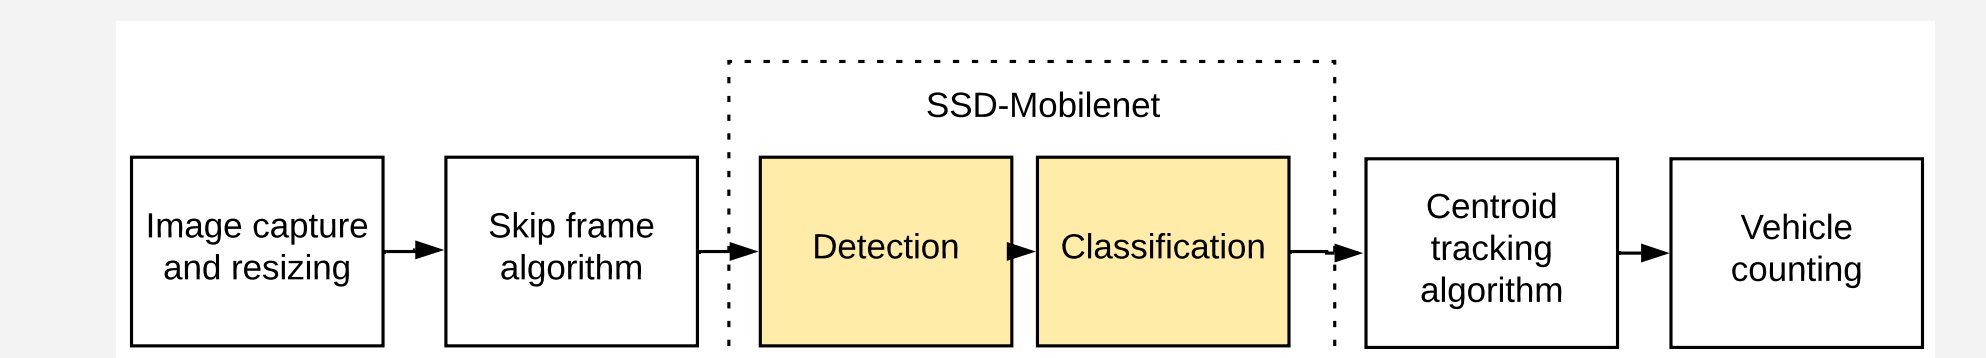


Figura 4: Estructura general del sistema de conteo con SSD-Mobilenet.




Figura 5: Esquema de skip-frame aplicado a las secuencias de video.

## Conclusiones

- ▶ Es posible alcanzar pseudo tiempo real en dispositivo embarcado.
- ▶ Servidor requiere GPU para mayor velocidad.
- ▶ Plataforma correcta para sensores estáticos.

## Agradecimientos

A Red CEDIA por el apoyo brindado mediante el proyecto "CEPRA - XII-2018-15 Movilidad".

## Referencias

- ▶ doi=10.1109/CoIcACI.2019.8781798
- ▶ doi=10.1109/ETCM.2018.8580283
- ▶ doi=10.1109/CoIcACI.2019.8781989
- ▶ doi=10.1007/978-3-030-35740-5\_12
- ▶ doi=10.1109/CoIcACI.2019.8781795
- ▶ doi=10.1117/12.2533380